نشریه ماشین‌های کشاورزی
جلد 8، شماره 1، نیمسال اول 1397، ص 29-15

Journal of Agricultural Machinery
Vol. 8, No. 1, Spring - Summer 2018, p. 15-29

تشخیص دو نوع علف‌هرز با استفاده از سیستم بینایی ماشین در راستای استفاده در سم‌پاشی خاص مکانی

سجاد سبزی[1]- یوسف عباس‌پور گیلانده[2*]- حسین جوادی‌کیا[3]

تاریخ دریافت: 1395/09/08
تاریخ پذیرش: 1396/02/23

چکیده

مبارزه هدفمند با علف‌های هرز یکی از اهداف اصلی در کشاورزی دقیق می‌باشد. یکی از روش‌هایی که مبارزه هدفمند را اجرایی می‌کند استفاده از سیستم‌های بینایی ماشین می‌باشد. به‌همین دلیل در این مطالعه یک سیستم بینایی ماشین مبتنی بر طبقه‌بند هیبرید شبکه عصبی مصنوعی– الگوریتم شبیه‌سازی تبرید-الگوریتم ژنتیک به‌منظور سم‌پاشی خاص مکانی براساس فیلم‌برداری در مزرعه ارائه گردید. به‌منظور آموزش الگوریتم سیستم بینایی ماشین، فیلم‌برداری از مزارع سیب‌زمینی رقم مارفونا واقع در استان کرمانشاه که در هفته ششم از مرحله رشد بودند انجام گرفت. مساحت مربوط به این مزارع 4 هکتار بود. در این مزارع دو نوع علف هرز با عناوین گل‌گندم و پنیرک وجود داشتند. به‌منظور بررسی پیچیده‌ترین شرایط کاری سیستم بینایی ماشین، پلتفرم با سرعت 0/103 متر بر ثانیه در شرایط نور طبیعی مزرعه‌ای یعنی شدت نور 1820 لوکس فیلم‌های مزرعه‌ای را جمع‌آوری کرد. در نهایت از ویدئوهای مزرعه‌ای 2581 شیء (به پیکسل‌های به‌هم پیوسته در یک فریم شیء گفته می‌شود) استخراج گردید کـه 1806 شـیء جهـت آمـوزش الگوریتم سیستم بینایی ماشین و 775 شیء باقیمانده جهت تست آن مورد استفاده قرار گرفـت. از میـان 206 خصوصـیت اسـتخراجی از هـر شـی، 6 خصوصیت مولفه دوم اضافی در فضای رنگی YCbCr، شاخص سبز منهای آبی فضای رنگی RGB، مجموع آنتروپی همسایگی 45 درجه، مومنـت قطری همسایگی صفر درجه، آنتروپی همسایگی 45 درجه، شاخص مؤلفه سوم اضافی فضای رنگی CMY با استفاده از روش هیبریـد ANN-PSO انتخاب شدند. نتایج نشان داد که سیستم طبقه‌بند با دقت 99/61 درصد قادر به طبقه‌بندی نمونه‌های مربوط به سه کلاس گیاه سیب‌زمینی، گل‌گندم و پنیرک می‌باشد.

واژه‌های کلیدی: بینایی ماشین، پردازش ویدئو، طبقه‌بندی، قطعه‌بندی، علف‌هرز

مقدمه

علف‌های هرز یکی از بزرگترین چالش هـا در بخـش کشـاورزی می‌باشند که به طور متوسـط 34% و در مـورد بعضـی از محصـولات خاص تا 70%، باعث کاهش بازدهی محصولات کشاورزی می‌شـوند (Monaco *et al*., 1981; Kazmi *et al*., 2015). اسـتفاده از علف‌کش‌ها به‌منظور مبارزه با علف‌های هرز از اواخر دهه 1940 رواج یافت (Gianessi and Reigner, 2007). به‌دلیـل مصـرف بـیش از اندازه‌ی این سموم شیمیایی مشکلاتی برای سلامت بشر، حیوانـات و محیط‌زیست به‌وجود آمده است. بنابراین محققان مختلف در سراسـر جهان به‌دنبال دستیابی به راه‌حل‌هایی جهت کاهش اسـتفاده از ایـن سموم می‌باشند. به‌طورکلی دو روش به‌منظور مدیریت کاهش میـزان مصرف علف‌کش‌ها وجود دارد، روش اول عبارت است از تهیه نقشـه توزیع علف‌های هرز در مزرعه و سپس ارائه نقشه بـه سـمپاش‌هـای هوشمند به‌منظور پاشش در این نـواحی. در همـین راسـتا روحـانی و مکاریان با استفاده از شبکه های عصبی چنـدی‌سـاز بـردار یـادگیر و پرسپترون چندلایه اقدام به پیش بینی و ترسیم نقشه توزیـع جمعیـت علف‌هرز تلخه کردند. نتایج نشان داد که شبکه عصبی آموزش دیـده چندی‌ساز بردار یادگیر دارای قابلیت بسیار بالایی در پیش‌بینی مکانی علف هرز در نقاط نمونه برداری نشده بـا خطـای تشـخیص کمتـر از 0/64 درصد بود. میزان خطای تشـخیص شـبکه عصـبی پرسـپترون چندلایه کمتر از 14/6 درصد به‌دست آمد. نقشـه هـای ترسـیم شـده نشان داد که توزیع لکه‌ای علف هرز امکان کنترل متناسب با مکان را

1و 2- به‌ترتیب دانشجوی دکتری و استاد، گـروه مهندسـی بیوسیسـتم، دانشـکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل
3- استادیار، گروه مهندسـی مکانیـک بیوسیسـتم، دانشـکده کشـاورزی، پـردیس کشاورزی و منابع طبیعی، دانشگاه رازی، کرمانشاه
(*- نویسنده مسئول: Email: abbaspour@uma.ac.ir)
DOI: 10.22067/jam.v8i2.60647

در مزرعه مورد مطالعه فراهم می‌سازد (Rohani and Makarian, 2011). روش دوم عبارت است از حرکت سم‌پاش هوشمند در مزرعه و پاشش زمان واقعی بر روی نواحی شامل علف هرز. از جمله روش‌هایی که به‌منظور استفاده بهینه از علف‌کش‌ها یا اصطلاحاً سم‌پاشی مبتنی بر مکان مورد توجه محققان قرار گرفته است، روش‌های مبتنی بر بینایی ماشین می‌باشد. در حقیقت هدف نهایی همه‌ی این روش‌ها، شناسایی نواحی مختلفی از زمین کشاورزی که دارای علف‌های هرز می‌باشند به‌منظور پاشش علف‌کش‌ها تنها برروی این نواحی می‌باشد (Asaei *et al.*, 2016). در همین راستا پررا و همکاران مطالعه‌ای بر روی طبقه‌بندی برگ‌های سه نوع علف هرز *E.crassipes*، *P.stratiotes* و *S.Auriculata* انجام دادند. در مرحله اول پایگاه داده محتوای 160 تصویر، شامل 51 تصویر *E.crassipes*، 46 تصویر *P.stratiotes* و 63 تصویر *S.Auriculata* تشکیل گردید. تصاویر با استفاده از دوربین دیجیتال در محفظه‌ای با پیش‌زمینه سفید گرفته شدند. در مرحله بعد، از تصاویر خاکستری به منظور قطعه‌بندی برگ علف‌های هرز از پس‌زمینه استفاده گردید. سپس پنج خصوصیت شکلی آمارهای زاویه پرتو[1]، توصیف‌گرهای فوریه، ثابت‌های ممانی، بعد فرکتال چند مقیاسی[2] و توصیف‌گر مقیاس تانسور به‌منظور طبقه‌بندی، از هر نمونه استخراج گردید. در نهایت از شبکه عصبی برای طبقه‌بندی استفاده شد. نتایج تجزیه و تحلیل دقت طبقه‌بندی بالای 80 درصد را نشان داد (Pereira *et al.*, 2012). یکی از مهم‌ترین اهداف تشخیص انواع علف‌های هرز کاهش میزان مصرف علف‌کش می‌باشد. برای دستیابی به این هدف، ویدئوها باید در مزرعه گرفته شوند، اما همانگونه که ذکر شد در این مطالعه تصاویر در آزمایشگاه گرفته شدند. بنابراین امکان استفاده عملی از این نتایج در مزرعه وجود ندارد. آکف و فیصل خان اعتقاد داشتند که طبقه‌بندی خودکار گیاهان، مهم‌ترین مرحله به‌منظور پیش‌بینی بیماری، تخمین رشد و سلامت و همچنین سم‌پاشی خاص مکانی آن‌ها می‌باشد. به‌همین منظور 14 نوع برگ با عناوین *Ficus carica*، *Malus domestica*، *Prunus armeniaca*، *Grewia asiatica*، *Syzygium cumini*، *Vitis vinifera*، *Psidium*، *Mangifera indica*، *Citrus aurantium*، *Litchi chinensis*، *Citrus limon*، *Eriobotrya japonica*، *Pyrus* و *Punica granatum* را مورد مطالعه قرار دادند. از این برگ‌ها، 817 قطعه عکس به‌منظور آموزش طبقه‌بند استفاده گردید. از هر برگ، خصوصیاتی در حوزه‌های مورفولوژی، شکلی و توصیف‌گرهای فوریه استخراج گردید. به‌منظور طبقه‌بندی از شبکه عصبی مصنوعی استفاده گردید. نتایج نشان داد که طبقه‌بند شبکه عصبی مصنوعی با استفاده از خصوصیات مورفولوژی، توصیف‌گرهای فوریه، خصوصیات شکلی و ترکیبی از همه خصوصیات، قادر به طبقه‌بندی این 14 نوع مختلف برگ به‌ترتیب با دقت 68/3، 77/8، 83/6 و 96/5 درصد بوده است (Aakif and FaisalKhan, 2015). در مجموع سیستم بینایی ماشین پیشنهادی برای این پایگاه داده دارای دقت قابل قبولی می‌باشد، اما در شرایط مزرعه‌ای شدت نور دائماً در حال تغییر می‌باشد و همین امر باعث تغییر در آستانه تعیین شده به‌منظور قطعه‌بندی می‌گردد و در نتیجه نتایج غلطی را به‌همراه خواهد داشت.

در تحقیق دیگر تانگ و همکاران 1300 قطعه عکس تحت شرایط نوری مختلف (آفتابی و و ابری) به‌منظور تشخیص علف‌های هرز از محصولات ردیفی تهیه کردند. دوربین بر روی کنسول تراکتور نصب شد. به‌منظور تشخیص خط مرکزی ردیف محصولات، از ترکیب دو روش طرح عمودی[3] و اسکن خطی[4] استفاده شد. نرخ هجوم علف‌های هرز تعدیل شده[5] به‌منظور تصمیم زمان واقعی راجع‌به تشخیص ردیف‌های محصولات از طریق مینیمم‌سازی نرخ خطای بیزین، استفاده شد. در نهایت نتایج نشان داد که روش پیشنهادی در این تحقیق نسبت به دو روش بیزین و ماشین‌بردار پشتیبان دارای برتری می‌باشد (Tang *et al.*, 2016). نتایج به‌دست آمده به‌منظور تشخیص انواع مختلف علف‌هرز از همدیگر دارای کاربرد نمی‌باشد، چون با استفاده از این روش تنها ردیف محصولات شناسایی شده و گیاهان بین هر دو ردیف به‌عنوان علف‌هرز تشخیص داده می‌شود. استفاده از بازتاب طیفی به‌منظور تشخیص گیاهان مختلف مورد تحقیق محققان مختلفی بوده است که از آن‌جمله می‌توان به (Panzi *et al.*, 2016) اشاره کرد. آن‌ها با تأکید به این نکته که علف‌های هرز تأثیر مخربی بر روی بازده محصولات کشاورزی دارند، اقدام به اجرای یک روش بر مبنای بینایی ماشین به‌منظور شناسایی ذرت و علف‌های هرز *Ranunculus repens*، *Cirsiumarvense*، *Sinapisarvensis*، *Stellariamedia*، *Tarraxacumofficinale*، *Poaannua*، *Poligonumpersicaria*، *Urticadioica*، *Oxaliseuropaea* و *Medicagolupulina* کردند. در روش پیشنهادی آن‌ها، علف‌های هرز و محصول ذرت با استفاده از تفاوت بازتاب طیفی از هم جدا می‌شدند. خصوصیات طیفی با استفاده از یک سیستم تصویربرداری ابر طیفی سوارشده بر روی یک پلت فرم استخراج شدند. در این تحقیق، سرعت حرکت پلت فرم 0/09 متر در ثانیه بود. از محصول ذرت و هر نوع علف هرز 164 نمونه (110 نمونه به‌منظور آموزش و 54 نمونه به‌منظور تست) به‌منظور طبقه‌بندی در سیستم‌های طبقه‌بند استفاده شد. آن‌ها از چهار طبقه‌بند مخلوط

1- Beam Angle Statistics (BAS)
2- Multiscale Fractal dimension (MS)
3- The vertical projection method
4- The linear scanning method
5- The classic Weeds Infestation Rate (WIR)

گاوسی[1]، نگاشت خود سازمانده[2]، ماشین بردار پشتیبان و شبکه خود رمزگذار[3] به منظور طبقه بندی استفاده کردند. نتایج نشان داد که روش‌های مخلوط گاوسی و نگاشت خودسازمانده با دقت 100 درصد محصول ذرت را شناسایی کردند، درحالی که روش های ماشین پشتیبان و شبکه خود رمزگذار با دقت 29/63 و 59/26 درصد محصول را شناسایی کردند. درصد طبقه‌بندی صحیح برای گونه‌های مختلف علف هرز بین 31 تا 98 درصد (با استفاده از روش مخلوط گاوسی)، 53 تا 94 درصد (با استفاده از روش نگاشت خودسازمانده)، 12/98 تا 68/52 درصد (با استفاده از روش ماشین بردار پشتیبان) و 9/63 تا 68/52 درصد (با استفاده از روش شبکه خود رمزگذار) بود.

بنابراین همانگونه که مشاهده گردید محققان مختلف، روش‌های گوناگونی را ارائه دادند که هر کدام از این روش‌ها معایب و مزایایی دارد. به‌دلیل حساسیت بالای کار در شرایط برخط معایب باید تا حدامکان کاهش یابد. به‌همین دلیل هدف از این مطالعه ارائه یک سیستم بینایی ماشین مبتنی‌بر پردازش ویدئو به‌منظور طبقه‌بندی گیاه سیب‌زمینی و دو نوع علف‌هرز رایج در زمین‌های تحت کشت سیب‌زمین یعنی گل‌گندم و پنیرک در راستای تحقق سم‌پاشی خاصی مکانی می‌باشد.

مواد و روش‌ها

سیستم بینایی ماشین ارائه شده در این مطالعه از دو قسمت اصلی تشکیل شده است، سیستم جمع‌آوری داده یا اصطلاحاً فیلم‌برداری و سیستم پردازش داده.

سیستم فیلم‌برداری

به‌منظور آموزش و تست سیستم بینایی ماشین، نیاز به فیلم‌برداری از مزرعه می‌باشد. فیلم‌برداری در مزارع سیب‌زمینی رقم مارفونا به مساحت 4 هکتار و در استان کرمانشاه بخش ماهیدشت انجام گرفت. سیب‌زمینی‌ها در هفته ششم از مرحله رشد خود بودند. علف‌های هرز رایج در این مزارع عبارتند از گل‌گندم و پنیرک. در گام اول یک پلتفرم به‌منظور فیلم‌برداری طراحی شد (شکل 1). این پلتفرم از سه قسمت اصلی شاسی فلزی، دوربین فیلم‌برداری (DFK 23GM021,CMOS, 120 f/s, Made in Germany) واحد تجزیه و تحلیل (لپ‌تاپ مجهزبه نرم‌افزار متلب 2015 و آفیس 2013) تشکیل شده است. به‌منظور بررسی پیچیده‌ترین شرایط کاری یک سیستم بینایی ماشین، پلتفرم با سرعت 0/103 متر بر ثانیه در شرایط

1- Mixture of Gaussians
2- Self-organising map
3- The auto-encoder network

نور طبیعی مزرعه‌ای یعنی شدت نور 1820 لوکس فیلم‌های مزرعه‌ای را جمع‌آوری کرد. در نهایت از ویدئوهای مزرعه‌ای 2581 شیء (به پیکسل‌های به‌هم پیوسته در یک فریم شیء گفته می‌شود) استخراج گردید که 1806 شیء جهت آموزش الگوریتم سیستم بینایی ماشین و 775 شیء باقیمانده جهت تست آن مورد استفاده قرار گرفت. شکل 2 فلوچارت کاری در این تحقیق را نشان می‌دهد.

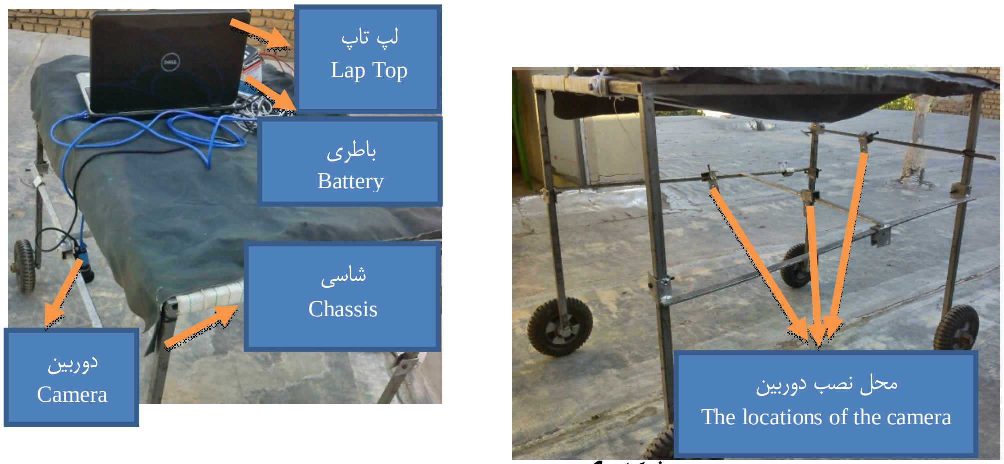
پیش‌پردازش و پس‌پردازش

قطعه‌بندی یکی از مهم‌ترین مراحل پیش‌پردازش در هر سیستم بینایی ماشینی می‌باشد. در واقع عملیات قطعه‌بندی، دقت سیستم بینایی ماشین را تحت تأثیر قرار خواهد داد، چرا که درصورت قطعه‌بندی نامناسب یا اشیاء به‌عنوان پس‌زمینه درنظر گرفته می‌شوند و یا پیکسل‌هایی از پس‌زمینه به‌عنوان شیء درنظر گرفته خواهند شد که در هر دو حالت سیستم طبقه‌بند دچار خطا می‌شود. به‌طورکلی دو نوع قطعه‌بندی وجود دارد، قطعه‌بندی نوع اول وظیفه جداسازی گیاهان مختلف و یا به‌اصطلاح اهداف مختلف در یک فریم از پس‌زمینه و قطعه‌بندی نوع دوم وظیفه جداسازی اشیاء مختلف در یک فریم را بر عهده دارد.

به‌منظور قطعه‌بندی نوع اول در این مطالعه فضاهای مختلف رنگی شامل RGB، HSV، HSI، CMY، YCbCr و YIQ مورد بررسی قرار گرفتند که درنهایت فضای رنگی HSV به‌عنوان فضای رنگی مناسب انتخاب شد. به‌منظور اعمال آستانه جهت جداسازی اشیاء از پس‌زمینه نیاز به انتخاب کانال مناسب می‌باشد. به‌همین دلیل کانال H این فضای رنگی انتخاب گردید. رابطه (1) میزان آستانه را بیان می‌کند.

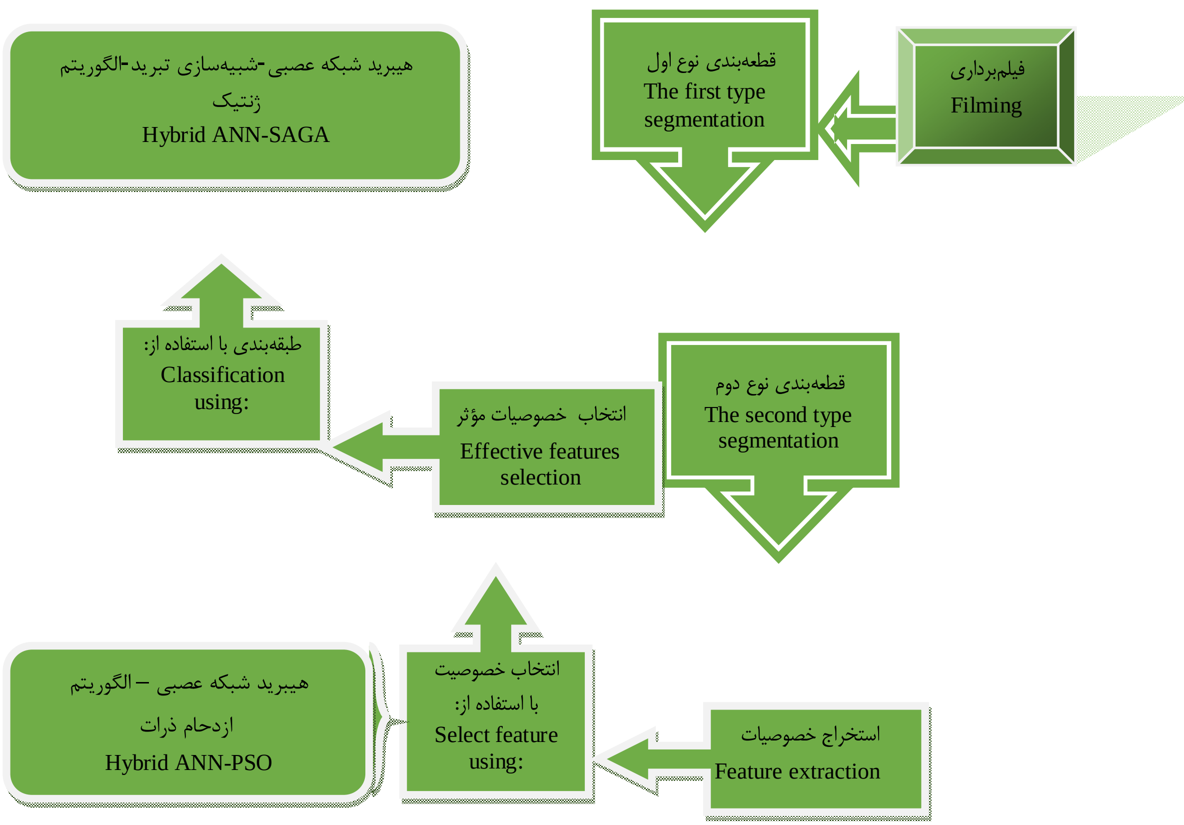
$$H\ (i,j) \le 0.2 \mid H(i,j) \ge 0.5 \qquad (1)$$

رابطه (1) بیان می‌کند در صورتی‌که مقدار هر پیکسل در کانال H از فضای رنگی HSV کمتر از 0/2 یا بیشتر از 0/5 باشد آن پیکسل مربوط‌به پس‌زمینه می‌باشد در غیر اینصورت گیاه محسوب می‌گردد. پس از انجام عملیات طبقه‌بندی به‌منظور استخراج خصوصیات شکلی از اشیاء نیاز به تبدیل آن‌ها به تصاویر دودویی می‌باشد، اما به‌دلیل وجود نویزهای مختلف که در اثر فیلم‌برداری در شرایط نور طبیعی به‌وجود آمده است نیاز به عملیات‌های پس‌پردازش می‌باشد. عملیات پس‌پردازش مورد استفاده در این مطالعه "بستن" بود. عملیات بستن ترکیبی از دو عملیات Dilation و Erosion می‌باشد که منجربه نرم شدن کانتورها می‌شود. این عملیات همچنین منجربه اتصال بین اجزای شکسته نازک، پر شدن حفره‌های نازک و کوچکتر از عضو ساختاری می‌شود (Gonzalez *et al*., 2004). شکل 3 مراحل مختلف قطعه‌بندی نوع اول و دوم و همچنین تصاویر دودویی را نشان می‌دهد.



شکل 1- سیستم تصویربرداری

Fig. 1. Filming system



شکل 2- فلوچارت روش پیشنهادی جهت تشخیص و طبقه‌بندی گیاه سیب‌زمینی و دو نوع مختلف علف‌هرز

Fig. 2. The flowchart of proposed method to detection and classification of potato plant and two different weeds



الف: تصویر اصلی
A: original image

ب: قطعه‌بندی نوع اول
B: The first type segmentation

پ: قطعه‌بندی نوع دوم
C: The second type segmentation



ث: تصویر دودویی بهبود یافته
E: Improved binary image

ت: تصویر دودویی
D: Binary image

شکل 3- مراحل مختلف قطعه‌بندی
Fig. 3. Different stages of segmentation

استخراج خصوصیات

به‌منظور شناسایی اشیاء استخراج شده از ویدئوها، نیاز به استفاده از خصوصیات هر شیء می‌باشد. به‌همین دلیل در این مطالعه 126 خصوصیت از میان خصوصیات رنگی و 80 خصوصیت از میان خصوصیات بافتی ماتریس هم‌اتفاقی سطح خاکستری استخراج گردید. پس از هر شیء جمعاً 206 خصوصیت استخراج گردید.

خصوصیات رنگی

خصوصیات رنگی به دو دسته 1- خصوصیات مربوط به میانگین و انحراف معیار و 2- شاخص‌های گیاهی تقسیم‌بندی می‌شوند. خصوصیات مربوط به میانگین و انحراف معیار عبارتند از میانگین مؤلفه اول، میانگین مؤلفه دوم، میانگین مؤلفه سوم، میانگین مؤلفه‌های اول، دوم و سوم، انحراف معیار مؤلفه اول، انحراف معیار مؤلفه دوم و انحراف معیار مؤلفه سوم فضاهای رنگی RGB، CMY، HSI، HSV، YIQ، YCbCr که جمعاً 42 خصوصیت را شامل می‌شود. 14 خصوصیات مربوط به شاخص سبزی برای هر فضای رنگی استخراج گردید، بنابراین 84 خصوصیت از این قسمت استخراج گردید. جدول 1 این 14 خصوصیت را برای فضای رنگی RGB نشان می‌دهد.

جدول 1- خصوصیات مربوط به شاخص‌های گیاهی

Table 1- The features related to vegetation indexes

خصوصیات استخراجی **Extracted features**	فرمول محاسبه خصوصیات استخراجی **The formula for calculating the extracted features**
مؤلفه اول RGB نرمال شده The normalized first component of RGB color space	$R_n = R/(R+G+B)$
مؤلفه دوم RGB نرمال شده The normalized second component of RGB color space	$G_n = G/(R+G+B)$
مؤلفه سوم RGB نرمال شده The normalized third component of RGB color space	$B_n = B/(R+G+B)$
کانال خاکستری Gray channel	$gray = 0.2898 \times R_n + 0.5870 \times Gn + 0.1140 \times B_n$
سبز اضافی Additional green (Woebbecke *et al.*, 1995)	$EXG = 2 \times G_n - R_n - B_n$
قرمز اضافی Additional red (Meyer et al., 1998)	$EXR = 1.4 \times R_n - G_n$
شاخص رنگی برای پوشش گیاهی استخراجی Color index for extracted vegetation cover (Kataoka *et al.*, 2003)	$CIVE = 0.441 \times R_n - 0.811 \times G_n + 0.385 \times B_n + 18.78$
تفاصل پارامترهای سبز اضافی و قرمز اضافی The subtraction between additional green and additional red (Meyer and Neto, 2008)	$EXGR = EXG - EXR$
شاخص تفاضل نرمال شده Normalized difference index (Woebbecke *et al.*, 1992)	$NDI = (G_n - B_n)/(G_n + B_n)$
شاخص سبز منهای آبی Green index minus blue (Woebbecke *et al.*, 1995)	$GB = (G_n - B_n)$
کنتراست قرمز آبی Red-blue contrast (Golzarian and Frick, 2011)	$RBI = (G_n - B_n)/(G_n + B_n)$
شاخص قرمز سبز Green-red index (Golzarian and Frick, 2011)	$ERI = (R_n - G_n) \times (R_n - B_n)$
شاخص سبز اضافی Additional green index (Golzarian and Frick, 2011)	$EGI = (G_n - R_n) \times (G_n - B_n)$
شاخص آبی اضافی Additional blue index (Golzarian and Frick, 2011)	$EBI = (B_n - G_n) \times (B_n - R_n)$

خصوصیات بافتی ماتریس هم‌اتفاقی سطح خاکستری

ماتریس هم‌اتفاقی سطح خاکستری محتـوای اطلاعـاتی دربـاره موقعیت قرارگیری پیکسل‌هـای بـا ارزش سـطح خاکسـتری مشـابه می‌باشد. در این مطالعه 20 خصوصیت مربوط به ماتریس هم‌اتفـاقی سطح خاکستری برای چهار حالت زاویه همسایگی 0، 45، 90 و 135 درجه استخراج گردید. بنابراین در کل 80 خصوصیت استخراج گردید. خصوصیات استخراجی در این حوزه در جدول 2 نشان داده شده است.

انتخاب خصوصیات مؤثر

انتخاب خصوصیات مؤثر در میان کل خصوصـیات اسـتخراجی از اشیاء، بسیار حساس می‌باشد. در حقیقت درصـورتی‌کـه کـل مراحـل فیلم‌برداری، پیش‌پردازش، پس‌پردازش و استخراج خصوصیات با دقت بالایی انجام شده باشد، با انتخاب یک روش ناکارآمد به‌منظور انتخاب خصوصیات مؤثر، کارایی سیستم بینایی ماشین کـاهش پیـدا خواهـد کرد. در این مطالعه استفاده از همه‌ی خصوصیات استخراجی به‌عنوان ورودی سیستم طبقه‌بند به‌منظـور طبقـه‌بنـدی گیـاه سـیب‌زمینـی و علف‌های هرز گل‌گنـدم و پنیـرک امکـان‌پـذیر نمـی‌باشـد. در واقـع خصوصیت‌های مختلف ممکن است که با هم در تضاد باشند و حتـی اگر هیچگونه تضادی نداشته باشـند، بـه‌دلیـل محـدودیت زمـانی در عملیات‌های برخط استفاده از همه آن‌ها ممکن نمـی‌باشـد. بنـابراین چاره‌ای جزء انتخاب خصوصیات مؤثر نمی‌باشد. روش‌هـای مختلفـی جهت انتخاب خصوصیات مؤثر در حوزه‌های آماری و هوش مصنوعی وجود دارند.

جدول 2- خصوصیات بافتی استخراج شده براساس ماتریس هم‌اتفاقی سطح خاکستری

Table 2- Texture features extracted based on the gray level co-occurrence matrix

شماره Number	خصوصیت Features	شماره Number	خصوصیت Features
1	همگنی Homogeneity	11	آنتروپی Entropy
2	اختلاف معکوس نرمال‌شده Inverse difference normalized (INN)	12	مومنت اختلاف معکوس نرمال‌شده Inverse difference moment normalized
3	ضریب تغییرات Coefficient of variation	13	اختلاف معکوس در همگنی Inverse difference (INV) is homogeneity
4	انحراف استاندارد Standard deviation	14	دومین مومنت قطری Second diagonal moment
5	سایه خوشه Cluster shade	15	اطلاعات اندازه همبستگی 1 Information measure of correlation1
6	برجستگی خوشه Cluster prominence	16	اطلاعات اندازه همبستگی 2 Information measure of correlation2
7	مجموع آنتروپی Sum entropy	17	عدم تجانس Dissimilarity
8	واریانس Variance	18	انرژی Energy
9	میانگین Mean	19	کنتراست Contrast
10	مومنت قطری Diagonal moment	20	همبستگی Correlation

در این مطالعه از روش هیبرید شبکه عصبی مصنوعی- الگوریتم بهینه‌سازی ازدحام ذرات به‌منظور انتخاب خصوصیت‌های مؤثر استفاده گردید. روش انتخاب خصوصیات مؤثر بدین صورت می‌باشد که در ابتدا الگوریتم بهینه‌سازی ازدحام ذرات از میان کل ورودی‌ها تعدادی را انتخاب کرده و به شبکه عصبی feedforward به‌منظور پیش‌بینی خروجی ارسال می‌کند. در مرحله بعد با استفاده از خروجی هدف و خروجی مدل میانگین مربعات خطا محاسبه شده و به الگوریتم بهینه‌سازی ازدحام ذرات ارسال می‌گردد. این کار تا زمانی ادامه می‌یابد که کمترین میزان خطا حاصل گردد و در نهایت خصوصیات مؤثر انتخاب می‌گردند. شبکه عصبی استفاده شده یک شبکه عصبی feedforward دارای دو لایه با تعداد نورون لایه میانی 10، تابع انتقال tansig و تابع آموزش trainlm بود.

طبقه‌بندی

مهم‌ترین و آخرین مرحله در سیستم بینایی ماشین پیشنهادی، مرحله طبقه‌بندی می‌باشد. در واقع خصوصیات مؤثر انتخاب شده در مرحله قبل به واحد طبقه‌بندی ارسال شده و واحد طبقه‌بندی وظیفه شناسایی گیاهان مختلف براساس این خصوصیات را دارد. درصورتی‌که طبقه‌بند مناسب جهت طبقه‌بندی استفاده نشود، سیستم بینایی ماشین دچار اشتباه خواهد شد و عملاً دارای کاربرد نمی‌باشد. طبقه‌بندهای مختلفی در حوزه‌های آماری و هوش مصنوعی به‌منظور طبقه‌بندی وجود دارند. نتایج نشان داده است درصورتی‌که ورودی طبقه‌بند زیاد باشد، داده‌ها پیچیده باشند و یا تعداد طبقه‌ها زیاد باشد اکثر روش‌های مربوط به هوش مصنوعی از روش‌های آماری بهتر عمل خواهند کرد. در مطالعه جاری، از طبقه‌بند هیبرید شبکه عصبی مصنوعی – الگوریتم شبیه‌سازی تبرید- الگوریتم ژنتیک به‌منظور طبقه‌بندی استفاده شد. در واقع وظیفه هیبرید الگوریتم شبیه‌سازی تبرید-الگوریتم ژنتیک بهینه‌سازی پارامترهای قابل تنظیم شبکه عصبی پرسپرون چندلایه می‌باشد. در حقیقت این شبکه دارای 5 پارامتر قابل تنظیم می‌باشد که دقت شبکه به تعیین مقادیر بهینه هر کدام از این پارامترها وابسته می‌باشد. در حقیقت الگوریتم هیبرید الگوریتم شبیه‌سازی تبرید- الگوریتم ژنتیک این پارامترها را به‌عنوان یک بردار در نظر گرفته و با تغییر مقادیر مربوط به این پارامترها و ارسال آن‌ها به شبکه عصبی و محاسبه و ثبت MSE در هر بار آموزش، در نهایت مقادیر مربوط به برداری که دارای کمترین میزان MSE باشند را به‌عنوان مقادیر بهینه پارامترها تعیین می‌کند. این پارامترها عبارتند از تعداد نورون‌ها (از 0 تا 25)، تعداد لایه‌ها (از 1 تا 3)، تابع انتقال (انواع مختلف تابع انتقال)، تابع آموزش شبکه بک پروپگیشن (انواع مختلف تابع آموزش) و تابع یادگیری وزن/ بایاس بک پروپگیشن (انواع مختلف تابع یادگیری). یکی از مهم‌ترین معیارها جهت استفاده از طبقه‌بندهای مختلف در سیستم‌های بینایی ماشین قابلیت اعتماد و اطمینان می‌باشد، این بدین معنی است که طبقه‌بند

در تکرارهای مختلف جهت آموزش دارای نتایج نزدیک به‌هم باشد. به‌همین دلیل در این مطالعه مرحله آموزش 20 بار تکرار گردید. به‌منظور بررسی عملکرد طبقه‌بند از شش معیار استفاده گردید. این معیارها عبارتند از Recall، Sensitivity، Precision، F_measure، Accuracy و Specificity. در ادامه به بررسی هر یک از این معیارها پرداخته می‌شود.

Recall, Sensitivity: چند درصد از نمونه‌های درست، به‌درستی تشخیص داده شده‌اند (رابطه 2).

$$\text{Recall} = \frac{TP}{TP + FN} \times 100 \quad (2)$$

Precision: چند درصد از خروجی‌های درست تشخیص داده شده، واقعاً درست است (رابطه 3).

$$Precision = \frac{TP}{TP + FP} \times 100 \quad (3)$$

F_measure: میانگین وزن‌دار هارمونیک Recall و Precision (رابطه 4)

$$\text{F_measure} = \frac{2 \times \text{Recall} \times Precision}{\text{Recall} + Precision} \quad (4)$$

Accuracy: درصد کل پاسخ‌های صحیح سیستم (رابطه 5)

$$\text{Accuracy} = \frac{TP + TN}{TP + FN + FP + TN} \times 100 \quad (5)$$

Specificity: چند درصد از نمونه‌های نادرست، به‌درستی تشخیص داده شده‌اند (رابطه 6).

$$\text{Specificity} = \frac{TP}{TP + FP} \times 100 \quad (6)$$

که TP برابر است با تعداد نمونه‌های هر کلاس که درست طبقه‌بندی شده‌اند. TN برابر است با تعداد نمونه‌های روی قطر اصلی ماتریس کنفیوژن منهای تعداد نمونه‌هایی که به‌درستی در کلاس موردنظر طبقه‌بندی شده‌اند. FN به‌صورت مجموع نمونه‌های افقی کلاس مورد بررسی منهای تعداد نمونه‌هایی که به‌درستی در کلاس موردنظر طبقه‌بندی شده‌اند تعریف می‌گردد. و در نهایت FP مجموع نمونه‌های عمودی کلاس مورد بررسی منهای تعداد نمونه‌هایی که به‌درستی در کلاس مورد نظر طبقه‌بندی شده‌اند، می‌باشد.

نتایج و بحث

انتخاب ویژگی‌های مؤثر

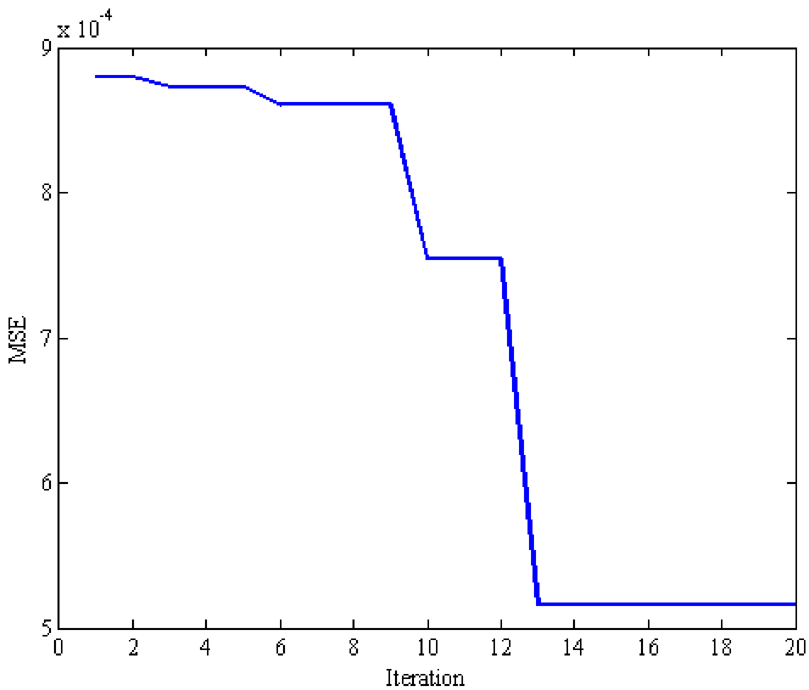
در میان 206 خصوصیت استخراجی از هر شیء در نهایت شش خصوصیت مؤثر با استفاده از روش هیبرید شبکه عصبی مصنوعی- الگوریتم بهینه‌سازی ازدحام ذرات انتخاب شدند. شکل 4 نمودار میانگین مربعات خطا برای ورودی‌های متفاوت در تکرارهای گوناگون را نشان می‌دهد. همانگونه‌که مشاهده می‌گردد از تکرارهای 1 تا 13 ورودی‌های جدید دارای میانگین مربعات کمتری نسبت به ورودی‌های قبلی بوده‌اند و در نهایت از تکرار 13 به بعد ورودی با شش خصوصیت انتخاب شده در این مطالعه دارای کمترین میزان میانگین مربعات خطا بوده‌اند. خصوصیات انتخابی به‌ترتیب عبارتند از مولفه دوم اضافی در فضای رنگی YCbCr، شاخص سبز منهای آبی فضای رنگی RGB، مجموع آنتروپی همسایگی 45 درجه، مومنت قطری همسایگی صفر درجه، آنتروپی همسایگی 45 درجه و شاخص مولفه سوم اضافی فضای رنگی CMY. همانگونه که مشاهده می‌گردد هیچ‌یک از خصوصیات شکلی در میان خصوصیات انتخابی نمی‌باشند و این بدین دلیل است که تابش مستقیم نور خورشید باعث درخشندگی در بعضی از قسمت‌های برگ شده و در سایر قسمت‌ها ممکن است که ایجاد سایه کند، بنابراین در زمان قطعه‌بندی یک گیاه به چندین قسمت تقسیم شده و همین امر باعث عدم انتخاب خصوصیات شکلی شده است.

آموزش هیبرید ANN-SA-GA

جدول 3 نتایج مربوط‌به انحراف معیار و میانگین چهار معیار نرخ طبقه‌بندی صحیح، میانگین مربعات خطا، ریشه میانگین مربعات خطا و میانگین مطلق خطا طبقه‌بند در 20 تکرار مرحله آموزش را نشان می‌دهد. همانگونه‌که مشاهده می‌گردد این معیارها دارای انحراف معیار کمی می‌باشند و این بدین معنی است که طبقه‌بند استفاده شده قابل اعتماد می‌باشد. شکل 5 نمودار باکس پلات مربوط‌به این چهار معیار طبقه‌بند را نشان می‌دهد. این شکل نشان می‌دهد که این معیارها در تکرارهای مختلف دارای مقادیر نزدیک به هم می‌باشند، بنابراین با استفاده از این شکل نیز می‌توان ادعا کرد که سیستم طبقه‌بند ارائه شده در این مطالعه دارای اعتماد می‌باشد. در نهایت در بهترین حالت آموزش شبکه عصبی مصنوعی، هیبرید SA-GA مقادیر بهینه مربوط به پارامترهای قابل تنظیم شبکه عصبی را تعیین کردند. مقادیر بهینه هر پارامتر در جدول 4 آورده شده است.

طبقه‌بندی با استفاده از هیبرید ANN-SA-GA

جدول 5 نتایج مربوط‌به طبقه‌بندی داده‌های تست با استفاده از طبقه‌بند هیبرید ANN-SA-GA برای بهترین حالت طبقه‌بندی را نشان می‌دهد. در این جدول شماره‌های 1، 2 و 3 به‌ترتیب مربوط به گل‌گندم، پنیرک و سیب‌زمینی می‌باشد. همانگونه‌که مشاهده می‌گردد در میان 775 نمونه مربوط‌به سه کلاس گل‌گندم، پنیرک و سیب‌زمینی تنها 3 نمونه به‌صورت اشتباهی طبقه‌بندی شده‌اند و این بدین معنی است که طبقه‌بند با دقت 99/61 درصد توانسته است که نمونه‌های مربوط‌به این سه کلاس را به‌درستی شناسایی کند.



شکل 4- نمودار میانگین مربعات خطا مربوط به مجموعه ورودی‌های مختلف در تکرارهای مختلف

Fig. 4. Mean square error graph related to different entries in various iterations

جدول 3- نتایج مربوط‌به انحراف معیار و میانگین چهار معیار ارزیابی در آموزش طبقه‌بند در 20 تکرار

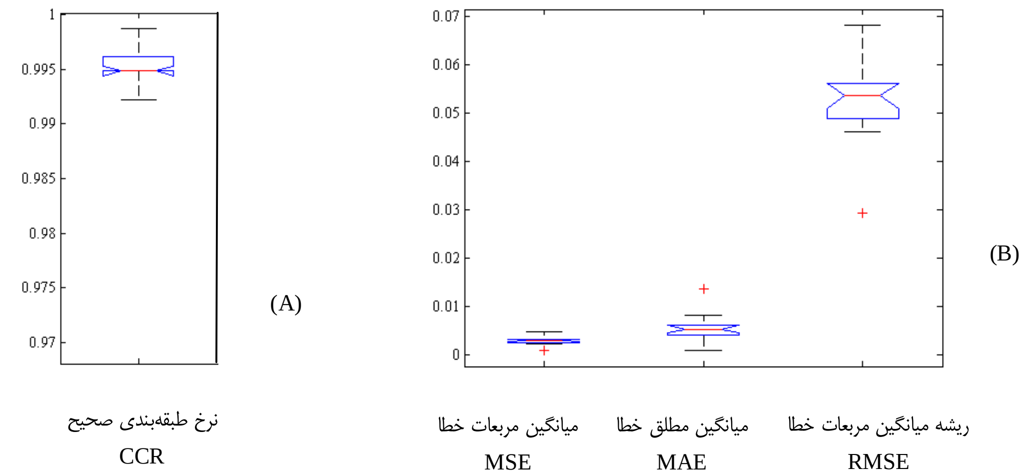
Table 3- The results of average and standard deviation related to four evaluation criteria in classifier train in 20 iterations

	میانگین مطلق خطا **Mean absolute error**	ریشه میانگین مربعات خطا **Root mean square error**	میانگین مربعات خطا **Mean square error**	نرخ طبقه‌بندی صحیح **Correct classification rate**
میانگین **Average**	0.0053	0.053	0.0029	99.53
انحراف معیار **Standard deviation**	0.0026	0.0082	0.00083	0.129

جدول 4- مقادیر بهینه پارامترهای شبکه عصبی مصنوعی تعیین شده توسط هیبرید شبیه‌سازی تبرید و الگوریتم ژنتیک

Table 4- The optimum values of the neural network parameters which were determined with SA-GA algorithm

تعداد نورون‌ها **The number of neuron**	تعداد لایه‌ها **The number of layer**	تابع انتقال **Transfer function**	تابع آموزش شبکه پس‌انتشار برگشتی **Backpropagation network training function**	تابع یادگیری وزن/بایاس پس‌انتشار برگشتی **Backpropagation weight/bias learning function**
The first layer: 25, the second layer: 21, the third layer: 21	3	The first layer: tansig, the second layer: satlin, the third layer: tribas	trainlm	learnwh



شکل 4- نمودارهای باکس‌پلات چهار پارامتر ارزیابی طبقه‌بند هیبرید ANN-SAGA برای 20 تکرار

Fig. 4. The box plot diagrams related to four parameters in hybrid ANN-SAGA classifier evaluation for 20 iterations

این میزان دقت برای شناسایی گیاهان در زمانی‌که سیستم بینایی ماشین در شرایط نور طبیعی کار می‌کند و شدت نور و شرایط طبیعی حاکم بر مزرعه در حال تغییر می‌باشد بسیار عالی است. جدول 5 نشان می‌دهد که هیچ‌کدام از نمونه‌های کلاس پنیرک به‌صورت اشتباهی در سایر کلاس‌ها طبقه‌بندی نشده است. این بدین معنی است که در میان 6 خصوصیت انتخابی جهت طبقه‌بندی هیچ شباهتی میان خصوصیات این کلاس و دو کلاس دیگر وجود ندارد. جدول 6 نتایج مربوطبه شش معیار ارزیابی عملکرد طبقه‌بند را نشان می‌دهد. همانگونه‌که مشاهده می‌گردد این شش معیار در اکثر کلاس‌ها دارای مقداری بالا 99 درصد می‌باشند. بنابراین از طریق این معیارها نیز می‌توان به عملکرد عالی سیستم طبقه‌بند پی برد.

جدول 5- نتایج طبقه‌بندی داده‌های تست در بهترین حالت طبقه‌بندی با استفاده از طبقه‌بند ANN-SAGA

Table 5- The results of classification related to testing data using ANN-SAGA classifier in the best state of classification

کلاس‌ها classes	**1**	**2**	**3**	**همه داده‌ها All data**	**درصد طبقه‌بندی اشتباه The percentage of incorrect classification (%)**	**درصد طبقه‌بندی کلی The percentage of general classification (%)**
1	197	0	1	198	0.5	
2	0	32	0	32	0.00	99.61
3	1	1	543	545	0.37	

جدول 6- شش معیار ارزیابی طبقه‌بند در بهترین حالت طبقه‌بندی

Table 6- Six evaluation criteria of classifier in the best state of classification

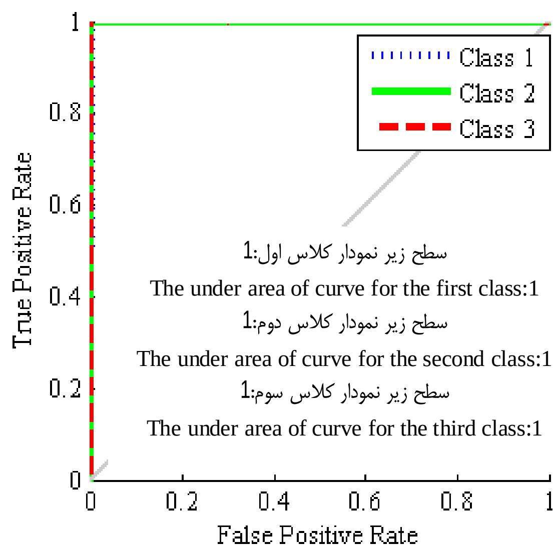
Class	**Recall**	**Precision**	**F_measure**	**Sensitivity**	**Accuracy**	**Specificity**
1	99.51	99.51	99.51	99.51	99.74	99.51
2	100	96.97	98.46	100	99.87	96.97
3	99.64	99.82	99.72	99.62	99.61	99.82

بررسی عملکرد طبقه‌بند با استفاده از نمودار خصوصیت عملیاتی دریافت‌کننده[1]

نمودار ROC به‌منظور بررسی عملکرد طبقه‌بندهای استفاده می‌گردد. شکل 5 نمودارهای ROC مربوطبه طبقه‌بند را نشان می‌دهد. همانگونه‌که مشاهده می‌گردد به‌ازای هر کلاس یک نمودار رسم شده است. بنابراین به دلیل وجود سه کلاس، سه نمودار رسم

1- Receiver Operating Characteristic (ROC)

شده است. محور افقی نمودار، FP (مجموع نمونه‌های عمودی کلاس مورد بررسی منهای تعداد نمونه‌هایی که به‌درستی در کلاس مورد نظر طبقه‌بندی شده‌اند) و محور عمودی آن، TP (برابر است با تعداد نمونه‌های هر کلاس که درست طبقه‌بندی شده‌اند) می‌باشد. هر اندازه که نمودار به خط نیمساز نزدیکتر باشد عملکرد طبقه‌بند در آن کلاس ضعیف‌تر می‌باشد. در نهایت اگر سطح زیر نمودار از سطح بالای آن کمتر باشد، طبقه‌بند عملاً دارای عملکرد بسیار ضعیفی می‌باشد. این منحنی مستقل از تعداد نمونه‌های هر کلاس می‌باشد و تنها براساس تعداد نمونه‌های به‌صورت اشتباه طبقه‌بندی شده عملکرد طبقه‌بندها را بررسی می‌کند.



شکل 5- نمودارهای ROC مربوط‌به طبقه‌بند ANN-SAGA برای سه کلاس گل‌گندم، پنیرک و سیب‌زمینی

Fig. 5. ROC diagrams related to ANN-SAGA classifier for three classes such as *Centaurea depressa M.B, Malvaneglecta and* Potato plant respectively

همانگونه‌که مشاهده می‌گردد هر سه نمودار به حالت تقریباً عمودی می‌باشند و این بدین معنی است که سیستم طبقه‌بند بهترین عملکرد را دارد. یک معیاری که برای بررسی این نمودارها استفاده می‌گردد سطح زیر منحنی می‌باشد. درصورتی‌که منحنی کاملا قائم باشد این سطح برابر با 1 می‌باشد و با فاصله گرفتن از حالت قائم، این میزان نیز کمتر می‌گردد. مقدار سطح زیر منحنی مربوط به این سه کلاس نیز در شکل 5 درج شده است. این مقدار برای هر سه منحنی تقریباً برابر با 1 می‌باشد. در پایان به‌منظور پی بردن به جایگاه تحقیق انجام شده در میان تحقیق سایر محققان نیاز به مقایسه نتایج می‌باشد. به‌دلیل جدید بودن تحقیق انجام شده (فیلم‌برداری در شرایط نور طبیعی مزرعه با سرعت 10/3 سانتی‌متر در ثانیه) امکان مقایسه مستقیم نتایج وجود ندارد. بااین‌حال از دو تحقیق (Pantazi *et al.*, 2016; Hlaing and Khaing, 2014) به‌منظور مقایسه استفاده شد. پانزی و همکاران با استفاده از روش ابرطیفی اقدام به طبقه‌بندی 10 نوع علف‌هرز مختلف کردند. آن‌ها با استفاده از چهار طبقه‌بند اقدام به طبقه‌بندی علف‌های هرز نمودند که بهترین نتایج طبقه‌بندی مربوط به روش مخلوط گاوسی بود. همانگونه‌که از جدول 5 مشاهده می‌گردد از مجموع 540 نمونه، 134 نمونه به‌صورت اشتباهی طبقه‌بندی شده است، بنابراین نرخ موقیت روش پیشنهادی 78/18 درصد می‌باشد. تحقیق دوم مربوط به هلینگ و خینگ می‌باشد. آن‌ها با استفاده از الگوریتم آستانه مساحت[1] اقدام به طبقه‌بندی چهار نوع علف‌هرز *Rape plant*، *Lanchon*، قازیاغی و *Kyautkut* کردند. همانگونه که جدول 5 نشان می‌دهد از مجموع 35 نمونه عکس تهیه شده از این علف‌های هرز 6 نمونه اشتباهی طبقه‌بندی شده است و بنابراین نرخ طبقه‌بندی صحیح سیستم 82/85 درصد بود. همانگونه‌که از جدول 5 مشاهده می‌گردد روش پیشنهادی در این مطالعه با تعداد نمونه‌های بیشتر از دو تحقیق دیگر دارای دقت به‌مراتب بالاتری می‌باشد.

شکل 6 دو نمونه از فریم‌های مورد بررسی توسط سیستم بینایی ماشین را نشان می‌دهد. همانگونه‌که مشاهده می‌گردد سیستم بینایی ماشین تمام اشیاء درون این فریم‌ها را به‌درستی شناسایی کرده است.

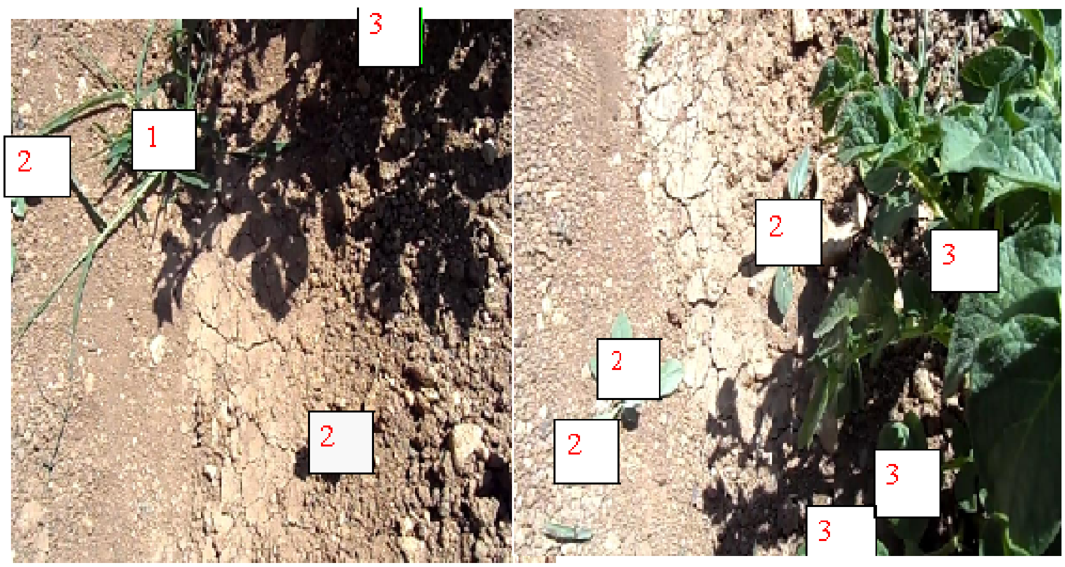
1- Area Thresholding Algorithm

بنابراین می‌توان ادعا کرد که سیستم پیشنهادی به‌منظور سم‌پاشی خاص مکانی دارای کارایی بسیار بالایی می‌باشد.

جدول 5- مقایسه نرخ موفقیت روش‌های مختلف برای طبقه‌بندی محصولات و علف‌های هرز

Table 5- Compares the success rate of the different methods for classification of crops and weeds

روش **Method**	تعداد نمونه‌ها **The number of samples**	تعداد نمونه‌های اشتباهی طبقه‌بندی شده **The number of incorrect classified samples**	درصد طبقه‌بندی **Accuracy rate (%)**
Proposed model	775 (testing data)	3	99.61
Pantazi *et al.*, (2016)	540	134	78.18
Hlaing and Khaing, (2014)	35	6	82.85



(A) (B)

شکل 6- دو نمونه مختلف از تشخیص سیستم بینایی ماشین در پردازش ویدئو. اعداد 3، 5 و 6 به‌ترتیب نمایانگر گل‌گندم، پنیرک و گیاه سیب‌زمینی می‌باشند.

Fig. 6. Two different samples from machine vision detection in video processing. No.3, No.5 and No.6 are *Centaurea depressa M.B, Malvaneglecta and* Potato plant respectively

نتیجه‌گیری

هدف از اجرای این تحقیق، ارائه یکی سیستم بینایی ماشین مبتنی بر پردازش ویدئو به‌منظور تحقق یکی از اهداف کشاورزی دقیق در جهت حفظ محیط‌زیست، یعنی سم‌پاشی خاص مکانی می‌باشد. نتایج نشان داد که سیستم طبقه‌بند هیبرید ANN-SA-GA با دقت 99/61 درصد قادر به شناسایی نمونه‌های مربوطبه سه کلاس گیاه سیب‌زمینی، گل‌گندم و پنیرک می‌باشد. مهم‌ترین نتایج به‌دست آمده در این تحقیق به‌صورت زیر می‌باشد.

1- مناسب‌ترین فضای رنگی به‌منظور قطعه‌بندی در شرایط نور طبیعی HSV و مناسب‌ترین کانال جهت اعمال آستانه مناسب کانال H این فضای رنگی می‌باشد.

2- ترکیبی از خصوصیات رنگی و خصوصیات بافتی ماتریس هم‌اتفاقی سطح خاکستری با استفاده از روش هیبرید ANN-PSO به‌عنوان خصوصیات مؤثر انتخاب شدند. خصوصیات انتخابی عبارتند از الف: مؤلفه دوم اضافی در فضای رنگی YCbCr، ب: شاخص سبز منهای آبی فضای رنگی RGB، پ: مجموع آنتروپی همسایگی 45 درجه، ت: مومنت قطری همسایگی صفر درجه، ث: آنتروپی

همسایگی 45 درجه، ج: شاخص مولفه سوم اضافی فضای رنگی CMY.

3- سطح زیر نمودار ROC برای تمام کلاس‌ها برابر با 1 می‌باشد.

4- همپوشانی گیاهان مختلف دقت طبقه‌بندی را پایین می‌آورد.

References

1. Aakif, A., and M. F. FaisalKhan. 2015. Automatic classification of plants based on their leaves. Biosystem Engineering 139: 66-75.
2. Asaei, H., A. Jafari, and M. Loghavi. 2016. Development and evaluation of a targeted orchard sprayer using machine vision technology. Journal of Agricultural Machinery 6 (2): 362-375. (In Farsi).
3. Gianessi, L. P., and N. P. Reigner. 2007. The value of herbicides in U.S. crop production. Weed Technology 21 (2): 559-566.
4. Golzarian, M. R., and R. A. Frick. 2011. Classification of images of wheat, ryegrass and brome grass species at early growth stages using principal component analysis. Plant Methods 7 (1): 7-28.
5. Gonzalez, R. C., R. E. Woods, and S. L. Eddins. 2004. Digital Image Processing Using MATLAB. Prentice Hall.
6. Hlaing, S. H., and A. S. Khaing. 2014. Weed and crop segmentation and classification using area thresholding. International Journal of Research in Engineering and Technology 3: 375-382.
7. Kataoka, T., T. Kaneko, H. Okamoto, and S. Hata. 2003. Crop growth estimation system using machine vision. in Proceedings of IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM).
8. Kazmi, W., F. J. Garcia-Ruiz, J. Nielsen, J. Rasmussen, and H. J. Andersen. 2015. Detecting creeping thistle in sugar beet fields using vegetation indices. Computers and Electronics in Agriculture 112: 10-19.
9. Meyer, G. E., and J. A. C. Neto. 2008. Verification of color vegetation indices for automated crop imaging applications. Computer and Electronic in Agriculture 63 (2): 282-293.
10. Meyer, G. E., T. Mehta, M. F. Kocher, D. A. Mortensen, and A. Samal. 1998. Textural imaging and discriminant analysis for distinguishing weeds for spot spraying. Transactions of the ASAE 41 (4): 1189-1197.
11. Monaco, T. J., and A. S. Grayson, and D. C. Sanders. 1981. Influence of four weed species on the growth, yield, and quality of direct-seeded tomatoes (*Lycopersicon esculentum*). Weed Science 29 (4): 394-397.
12. Pantazi, X. E., D. Moshou, and C. Bravo. 2016. Active learning system for weed species recognition based on hyperspectral sensing. Biosystems engineering xxx, ARTICLE IN PRESS.
13. Pereira, L. A. M., R. Y. M. Nakamura, G. F. S. d. Souza, D. Martins, and J. P. Papa. 2012. Aquatic weed automatic classification using machine learning techniques. Computers and Electronics in Agriculture 87: 56-63.
14. Rohani, A., and H. Makarian. 2011. Preparation weed management maps using artificial neural networks aimed application at Precision Agriculture. Journal of Agricultural Machinery Engineering 1: 74-83. (In Farsi).
15. Tang, J. L., X. Q. Chen, R. H. Miao, and D. Wang. 2016. Weed detection using image processing under different illumination for site-specific areas spraying. Computers and Electronics in Agriculture 122: 103-111.
16. Woebbecke, D., G. E. Meyer, K. V. Bargen, and D. A. Mortensen. 1995. Color indices for weed identification under various soil, residue, and lighting conditions. Transactions of the ASAE 38 (1): 259-269.
17. Woebbecke, D. M., G. E. Meyer, K. V. Bargen, and D. A. Mortensen. 1992. Plant species identification, size, and enumeration using machine vision techniques on near-binary images. Optics in Agriculture and Forestry 1836: 208-219.

Journal of Agricultural Machinery
Vol. 8, No. 1, Spring - Summer 2018, p. 15-29

نشریه ماشین‌های کشاورزی
جلد 8، شماره 1، نیمسال اول 1397، ص 29-15

Detection of Two Types of Weed through Machine Vision System: Improving Site-Specific Spraying

S. Sabzi[1]- Y. Abbaspour-Gilandeh[2*]- H. Javadikia[3]

Received: 28-11-2016
Accepted: 13-05-2017

Introduction

With increase in world population, one of the approaches to provide food is using site-specific management system or so-called precision farming. In this management system, management of crop production inputs such as fertilizers, lime, herbicides, seed, etc. is done based on farm location features, with the aim of reducing waste, increasing revenues and maintaining environmental quality. Precision farming involves various aspects and is applicable on farm fields at all stages of tillage, planting, and harvesting. Today, in line with precision farming purposes, and to control weeds, pests, and diseases, all the efforts of specialists in precision farming is to reduce the amount of chemical substances in products. Although herbicides improve the quality and quantity of agricultural production, the possibility of applying inappropriately and unreasonably is very high. If the dose is too low, weed control is not performed correctly. Otherwise, If the dosage is too high, herbicides can be toxic for crops, can be transferred to soil and stay in it for a long time, and can penetrate to groundwater. By applying herbicides to variable rate, the potential for significant cost savings and reduced environmental damage to the products and environment will be possible. It is evident that in large-scale modern agriculture, individual management of each plant without using some advanced technologies is not possible. using machine vision systems is one of precision farming techniques to identify weeds. This study aimed to detect three plant such as *Centaurea depressa M.B, Malvaneglecta and* Potato plant using machine vision system.

Materials and Methods

In order to train algorithm of designed machine vision system, a platform that moved with the speed of 10.34 cm/s was used for shooting of Marfona potato fields. This platform was consisted of a chassis, camera (DFK23GM021,CMOS, 120 f/s, Made in Germany), and a processor system equipped with Matlab 2015 version. The video camera was installed in 60-centimeter height above the ground level. Therefore, all plants in the camera field of view (whether on the crops row or between the rows) were analyzed. This study conducted on 4 hectares of potato fields in Kermanshah–Iran (longitude: 7.03°E; latitude: 4.22°N). The most suitable color space for segmentation plants was HSV color space and most suitable channel of applying threshold was the H channel. In this study, features in two areas of color features, texture features based on gray co-occurrence matrix were extracted. Ultimately, 126 color features and 80 texture features were extracted from each object. In final six features among 206 features were selected.

Results and Discussion

Among 206 extracted features, six effective features including the additional second component of the YCbCr color space, green index minus blue in RGB color space, sum entropy in the neighborhood of 45 degree, diagonal moment in the neighborhood of 0 degree, entropy in the neighborhood of 45 degree, additional third component index in CMY color space were selected using hybrid ANN-PSO. This means that, two set features have the same effect over plants. The result shows that hybrid ANN-SAGA classified *Centaurea depressa M.B, Malvaneglecta and* Potato plant with 99.61% accuracy. This accuracy is high and this meant that 1. These plants have different 6 selected features, 2. The classifier is very powerful to classify.

1 and 2- PhD student and Professor, Department of Biosystems Engineering, Faculty of Agricultural and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran
3- Assistant Professor, Department of Biosystems Engineering, College of Agriculture, Razi University, Kermanshah, Iran
(*- Corresponding Author Email: abbaspour@uma.ac.ir)

Conclusions

1. Plants with similar features make the classification process complicated and less accurate.
2. The presence of shadow on the plants’ leaves reduces the accuracy of the classification.

Keywords: Classification, Machine vision, Segmentation, Video processing, Weeds